

# 土壤有机质含量田间实时测定方法\*

何东健 陈 煦

(西北农林科技大学机械与电子工程学院, 陕西杨凌 712100)

**摘要:** 为了实现对土壤有机质含量的快速测定,以关中壤土为材料,研究基于光谱分析的土壤有机质含量测定方法。首先用机载便携式近红外光谱仪采集土壤样本在波长 900 ~ 1 700 nm 范围的漫反射光谱,并对异常样本进行判别和剔除以提高建模精度,在比较 2 种不同样本划分方法对模型影响的基础上,用连续投影算法(SPA)对建模变量进行最优波长选择,然后通过 3 种线性建模方法对有机质含量预测结果进行分析,探明偏最小二乘法(PLS)方法效果最好,并建立了径向基(RBF)神经网络预测模型。测试集样本实验结果表明,用 PLS 建立的预测模型有机质含量测定值和预测值之间的决定系数为 0.801 9,均方根误差为 0.179 4;用 RBF 神经网络建模的决定系数和均方根误差分别为 0.828 1 和 0.164 6,两种模型均具有较高的精度,可对有机质含量进行快速预测。

**关键词:** 土壤 有机质含量 光谱分析 预测模型 偏最小二乘法 径向基神经网络

**中图分类号:** S158.3; O433.4 **文献标识码:** A **文章编号:** 1000-1298(2015)01-0127-06

## Real-time Measurement of Soil Organic Matter Content in Field

He Dongjian Chen Xu

(College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China)

**Abstract:** In order to achieve rapid measurement of soil organic matter content, Lou soil was prepared to study soil organic matter determination method based on spectral analysis. Firstly, the soil diffusion reflectance spectrum with range of 900 ~ 1 700 nm was collected by using the portable spectrograph, and the abnormal samples were identified and removed to improve the accuracy. After that, based on the comparison of two different sample dividing methods, the optimal wavelengths of the modeling variables were selected by using successive projections algorithm (SPA). Then, the effect of prediction results of organic matters was analyzed with three linear modeling methods (MLR, PCR, PLS). The results indicated that PLS worked better. The RBF neural network was also built. The results of testing sets showed that the coefficient of determination and root mean square error between measured value and predicted value was 0.801 9 and 0.179 4 with PLS model, and 0.828 1 and 0.164 6 with RBF neural network, respectively. Both of them showed a high accuracy which could be used for the fast prediction of the soil organic matter content.

**Key words:** Soil Organic matter content Spectrometry analysis Prediction model Partial least squares RBF neural network

### 引言

土壤养分是影响农作物生长的主要因素之一,农作物的生长需要从农田土壤中获得水分和各种营养物质,其中土壤有机质是土壤重要的组成部分,其

含量是衡量农田肥沃程度的重要指标<sup>[1]</sup>。准确掌握土壤有机质含量的变化不但可以精准满足作物生长需求,提高产量,而且可以更加有效地调整物质生态的投入,避免浪费<sup>[2]</sup>。因此,迫切需要对土壤有机质进行快速检测。

传统的土壤有机质检测方法采用某些化学试剂溶液来提取测定,步骤繁琐,耗时费工,很难实现实时检测<sup>[3]</sup>。近红外光谱分析技术(Near infrared spectrometry, NIRS)具有快速、无损、低成本检测的特点<sup>[4]</sup>,它可以在短时间内分析大量土样、实现土壤参数的实时在线测量,更加适应精准农业的发展要求,得到了农业领域学者的高度关注<sup>[5-6]</sup>。

从20世纪70年代开始,国外学者就开始对土壤物质含量与光谱特征进行研究,表明土壤有机质含量和可见光及近红外反射率具有相关性<sup>[7]</sup>。赵锁劳等在国内首次采用近红外光谱分析法对我国黄土区土壤水分、有机质和总氮含量进行评价分析<sup>[8]</sup>。近年来,孙建英等对土壤水分、有机质含量、硝态氮含量等进行了预测<sup>[9]</sup>。研究表明近红外光谱法能检测土壤有机质含量,但很少针对西北地区的土壤质地,且研究一般采用通用光谱仪在室内进行实验,对土壤样本的处理相对复杂,不能直接应用于田间实时在线检测,光谱预处理效果不甚明显,不同建模方法对于建立的土壤有机质预测模型影响较大,且土壤有机质预测模型的预测结果难以达到应用要求的效果<sup>[10-13]</sup>。本文以开发田间实时有机质测定仪为目标,以陕西杨凌关中壤土为研究对象,采用可用于机载的便携式光谱仪,测定土壤样本在900~1700 nm波长范围的近红外光谱,研究并建立土壤有机质含量的预测模型,为田间实时有机质测定仪的开发提供技术依据。

## 1 供试样本及光谱获取

### 1.1 样本采集与处理

供试土壤采自西北农林科技大学试验田及周边田块,土壤类型为关中壤土,种植作物为玉米。为了使样本的营养含量覆盖较大的范围,采用十字法选取采样点,采样深度为0~20 cm。采土时将每个采样点地表碎石与植物清除,挖20 cm深的矩形坑,然后紧贴坑壁铲下厚约5 cm的一层土,收集装袋,共采集土壤样本150份。为了使样本尽量接近于农田实测条件,不对土壤进行研磨,自然风干后过2 mm筛。将土壤置于直径9 cm、高1 cm的培养皿中装满,表面用尺刮平制成样本。将样本分为2份,一份用于化学分析,另一份用于近红外分析。

### 1.2 光谱采集仪器与方法

为开发实时田间养分测定仪,综合考虑光谱采集仪性能、成本和尺寸等因素,选用美国CONTROL DEVELOPMENT公司便携式近红外光谱仪,该光谱仪为阵列检测型,设备响应频谱范围900~1700 nm,采样间隔为1 nm,且稳定性和抗干扰性好、扫描速度

快、体积小、性能优越,适合野外现场的在线检测。图1为光谱采集系统实物图,35 W卤素灯光源与光纤探头安装在光谱仪自带支架上,二者呈8°夹角,光纤探头距土壤样本距离经实验确定为10 cm,通过光纤与光谱仪连接,光谱仪将反射光谱解析后通过USB连接传输给计算机,通过软件CDI Spec32可以控制光源的开闭与光纤探头的扫描时间。在波长900~1700 nm范围采集150份样本光谱,采样间隔为1 nm,每份样本采集5次光谱,取平均值后的光谱曲线如图2所示。




图1 光谱采集设备

Fig. 1 Equipment of spectral acquisition system

1. 35 W 卤素光源 2. 近红外光谱仪 3. 配套支架 4. 光纤探头  
5. 计算机显示器




图2 土壤的近红外漫反射光谱图

Fig. 2 Near-infrared diffuse reflectance spectra of soil

### 1.3 样本有机质含量测定

土壤样本的有机质含量采用重铬酸钾容量法测定,在研磨称量后的样本中加入定量的重铬酸钾-硫酸溶液,在电加热条件下,使土壤中的有机质氧化,剩余的重铬酸钾用硫酸亚铁标准溶液滴定,并以二氧化硅为添加剂作实际空白标定,根据氧化前、后氧化剂质量差值,计算出土壤有机质的含量<sup>[14]</sup>。样本的有机质质量比如表1所示。

表1 土壤样本的有机质质量比统计结果

Tab. 1 Descriptive statistics of soil sample organic matter content measurements

样本数	最大值/ ( $\text{mg}\cdot\text{kg}^{-1}$ )	最小值/ ( $\text{mg}\cdot\text{kg}^{-1}$ )	平均值/ ( $\text{mg}\cdot\text{kg}^{-1}$ )	方差
150	18.67	7.45	14.17	0.197

本文用决定系数  $R^2$  和均方根误差 RMSE (Root mean square error) 来评价模型, 决定系数越高、均方根误差越小则模型的精度越高<sup>[15]</sup>。

## 2 预测模型建立方法

### 2.1 异常样本的剔除

异常样本会严重影响建立模型的预测精度。产生异常样本的主要原因是测量物质含量时的人为读数误差和由光谱仪本身误差、样本前处理不当、温度和湿度等外界因素干扰等引起光谱数据的误差<sup>[16]</sup>。异常样本包括有机质含量测定值和光谱数据信息, 本文选用 3 倍标准差准则和主成分分析 (Principal component analysis, PCA) 得分图, 对有机质含量和样本光谱数据的异常值进行判别, 再用偏最小二乘法 (Partial least squares, PLS) 建立土壤有机质含量预测模型, 逐一检测剔除异常值后的预测结果, 依据其预测效果决定是否将该异常值剔除。在 Unscrambler 9.7 中用 PCA 对样本的光谱数据异常值进行判断, 软件按样本方差和得分情况标记出异常值如图 3 所示, 共判别出 10 个异常值。举例说明剔除过程: 剔除前用原始光谱建模得到决定系数  $R_c^2$  为 0.587 1, 建模均方根误差 RMSEC 为 0.126 6, 根据图可知 7 号可能为异常样本, 将其剔除, 剔除后  $R_c^2$  为 0.597 2, RMSEC 为 0.125 4, 结果变化不大, 由此判断 7 号样本不是异常值, 故将其保留; 由图知 9 号也可能为异常样本, 将其剔除, 剔除后  $R_c^2$  提高到 0.753 3, RMSEC 降低到 0.091 47, 因此判断 9 号样本为异常样本, 可将其剔除; 以此对每个判断出的可能异常样本进行逐一检测, 剔除异常值 9 个, 分别为: 1、3、9、17、18、23、50、55、140 号样本。然后在 Excel 2003 里用 3 倍标准差对有机质含量的异常值进行了判断, 其中 8 号样本为异常值。将判断出的异常值剔除, 得到准确的光谱数据进行后续实验。

### 2.2 模型样本的划分

对剔除异常值的光谱数据进行预处理, 经预备实验对比知, 变量标准化 (Standard normalized

variate, SNV) 可有效降低由于样品间本身成分含量信息的差异性, 经 SNV 后采用去趋势算法 (Detrending) 又可消除漫反射光谱的基线漂移<sup>[17]</sup>, 用预处理后的样本建立模型便可对土壤的有机质含量进行定量分析, 但建模集和预测集样本的划分对建立的模型精度有较大的影响<sup>[18]</sup>, 为了探明较优的划分方法, 选择 Kennard - Stone (KS) 样本划分和 X - Y 共生矩阵法 (Sample set partitioning based on joint X - Y distance, SPXY)<sup>[19]</sup> 等进行实验。

用不同样本划分方法划分样本, 并用 PLS 方法建立土壤有机质含量预测模型, 预测的决定系数  $R_p^2$  和均方根误差 RMSEP 如表 2 所示。由表 2 可以看出, SPXY 样本划分方法结果更好。

表 2 不同样本划分方法的有机质预测模型结果

Tab. 2 Results of predicting organic matter content model based on different sample division methods

样本划分方法	$R_c^2$	RMSEC	$R_p^2$	RMSEP
KS	0.898 2	0.063 9	0.640 7	0.127 2
SPXY	0.907 9	0.060 8	0.664 7	0.127 3

### 2.3 特征波长的选择

由于定量分析时所需的样本数量大, 且每个样本的光谱数据存在谱峰重叠问题, 导致光谱信息冗余, 特征吸收峰不明显, 因此需要寻找对模型起关键作用的有效波长。连续投影法 (Successive projections algorithm, SPA) 是通过对光谱数据投影映射选取原始数据中的少数波长, 可尽可能多地概括样本光谱信息, 最大程度避免信息重叠<sup>[20]</sup>。

假设初始的迭代向量为  $\mathbf{x}_{k(0)}$ , 需要提取的变量个数为  $N$ , 原始光谱矩阵的  $p$  个变量表示为  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_p$ , 则 SPA 算法步骤为:

(1) 任选光谱的一列  $j$  作为第 1 个变量, 记作  $\mathbf{x}_0$ , 把没有选入的列向量集合记作  $\mathbf{s}$ , 其中  $\mathbf{s} = \{j, 1 \leq j \leq J, j \notin \{k(0), k(1), \dots, k(n-1)\}\}$ 。

(2) 分别计算  $\mathbf{x}_j$  对剩余列向量的投影

$$\mathbf{p}_{x_j} = \mathbf{x}_j - (\mathbf{x}_j^T \mathbf{x}_{k(n-1)}) \mathbf{x}_{k(n-1)} (\mathbf{x}_{k(n-1)}^T \mathbf{x}_{k(n-1)})^{-1} \quad (j \in \mathbf{s})$$

记  $k(n) = \arg(\max \|\mathbf{p}_{x_j}\|, j \in \mathbf{s})$ 。

(3) 令  $\mathbf{x}_j = \mathbf{p}_{x_j}, j \in \mathbf{s}; n = n + 1$ , 如果  $n < N$ , 循环计算, 最终提取的变量为:  $\{ \mathbf{x}_{k(n)} = 0, 1, \dots, N - 1 \}$ <sup>[21]</sup>。

对样本划分后的全段光谱数据进行 SPA 分析, 经交叉验证得到的 RMSE 和选定的 14 个特征波长分布如图 4 所示。从图 4 可以看出, 当选取 14 个特征波长时, 模型 RMSE 值达到最小为 0.085 9。故从 800 个波长中选择其中的 14 个波长, 可滤除 98.25% 的变量。用选中的波长建立 PLS 模型,  $R_c^2$





图 3 样本的 PCA 得分图

Fig. 3 PCA score plot of samples

为 0.855 7, RMSEC 为 0.113 4,  $R_p^2$  为 0.795 2, RMSEP 为 0.145 8。与用全波段建立的模型结果对比可以看出,虽然  $R_c$  略微下降,但  $R_p$  基本持平,且



RMSEP 有所降低,因此,用连续投影波长选择方法得到的预测结果比较满意,可用于后续实验的 PLS 定量分析。




图4 SPA得到的RMSE和波长选择分布图

Fig.4 Distribution of RMSE and selected variable wavelength obtained by SPA

(a) 选择的波长数 (b) 波长选择分布图

## 2.4 建模方法

近红外光谱定量分析常用方法有多元线性回归 (Multiple linear regression, MLR)、主成分回归 (Principal component regression, PCR) 和最小二乘法回归 (PLS) 等线性分析方法,以及神经网络等非线性方法,本文分别用 MLR、PCR、PLS 和 RBF 神经网络方法建模并分析预测效果,以确定较优的建模方法。

### 2.4.1 线性建模方法

(1) 多元线性回归方法:又称逆最小二乘法,只要知道样本中某些组分的含量,便可建立模型,但要求参与建模的变量数不能超过样本的数量。所以实验时先对光谱数据进行主成分分析,然后用主成分分析得到的得分矩阵建立 MLR 模型。

(2) 主成分回归方法:该方法可有效克服 MLR 方法存在的输入变量间共线性引起算法的不稳定性,在利用光谱有用信息的前提下,忽略次要主成分,可有效抑制噪声对模型的影响,从而提高模型的预测能力。本文根据实验选取 20 个主成分建立模型。

(3) 偏最小二乘法:该方法首先对光谱数据进行运算,求取主因子或隐含变量,再根据主因子或隐含变量的累积贡献率得分值建立模型。PLS 的计算过程同时考虑了光谱数据变量和化学指标数据变量,所建模型性能更优。为了和主成分回归对比,同样选取 20 个主成分因子数建立模型,对模型采用交叉验证的方法。

3 种建模方法得到的评价结果如表 3 所示。由表 3 可知,PLS 的建模方法的预测效果相对更好。

### 2.4.2 非线性建模方法

通常,光谱参数与样本含量测定值之间具有非线性,且仪器噪声及基线漂移等也会引起非线性现

表3 不同线性建模方法的结果对比

Tab.3 Results of different linear modeling methods				
建模方法	$R_c^2$	RMSEC	$R_p^2$	RMSEP
MLR	0.770 3	0.103 2	0.666 5	0.140 2
PCR	0.723 1	0.132 0	0.694 7	0.152 1
PLS	0.913 5	0.075 2	0.735 9	0.120 9

象。尽管 PLS 法在一定程度上可以校正非线性因素,但在非线性严重的情况下难以获得理想效果。人工神经网络法 (Artificial neural network, ANN) 具有自学习、自组织、自适应能力,并具有良好的非线性表达能力<sup>[22]</sup>,经过预备实验,本文选用 RBF 神经网络法进行非线性校正。RBF 网络由 1 个隐含层和 1 个线性输出层组成。隐含层是高斯径向基函数,输出层是线性激活函数。输入层有 100 个神经元,隐含层神经元数量经对比实验确定为 115 个;输出层 1 个神经元,对应土壤有机质含量的预测值。

训练时,从剔除异常样本的样本集中随机抽取 100 个样本(每个样本去除原始光谱边缘不平滑区域,取波长 900 ~ 1 660 nm 的光谱信息)作为输入 RBF 神经网络,确定误差目标为 0.002 7,其他参数设置为默认值。网络训练好后,将剩余的 40 个土壤样本作为预测集输入 RBF 网络进行预测。

## 3 实验结果及分析

### 3.1 PLS 线性建模方法实验结果

几种线性建模方法对比可知 PLS 方法的预测效果更好,故本文用 PLS 方法建立预测模型。但实际计算时,PLS 把矩阵的分解和回归合并为一步,结合了多元线性回归、典型相关分析和主成分分析<sup>[23]</sup>。故用 PLS 建立模型时,主因子变量的个数至关重要,当主因子变量个数较少时,无法反映样本的

光谱特性,造成模型精度下降,而主因子变量个数过多时,又会引入干扰噪声。为探明最优主因子变量个数,先随机抽取 40 个土壤样本作为预测集,剩余的 100 个土壤样本作为建模集,然后选择主因子变量个数分别为 7、9、11、13 和 14,建立光谱反射率和土壤有机质之间的 PLS 标定模型,建模集决定系数  $R_c^2$  和均方根误差 RMSEC,预测样本集  $R_p^2$  和均方根误差 RMSEP 如表 4 所示。从表 4 可知,当选择的主成分因子数为 11 时,模型结果最好,建模和预测的决定系数和均方根误差分别为 0.946 8、0.805 8 和 0.059 8、0.117 9,土壤有机质 PLS 模型的建模效果如图 5a 所示。

用建立的有机质含量预测模型,对 40 个预测集样本进行预测,土壤有机质含量的预测值和测定值之间的关系如图 5b 所示。预测决定系数  $R_p^2$  为 0.801 9,预测均方根误差 RMSEP 为 0.179 4。




表 4 土壤有机质含量的 PLS 结果分析  
Tab. 4 PLS modeling results of soil organic matter content

主因子变量数	$R_c^2$	RMSEC	$R_p^2$	RMSEP
7	0.875 2	0.091 5	0.746 7	0.143 3
9	0.900 9	0.083 3	0.759 9	0.138 0
11	0.946 8	0.059 8	0.805 8	0.117 9
13	0.913 5	0.073 2	0.735 9	0.120 9
14	0.913 5	0.075 2	0.735 9	0.120 9

### 3.2 RBF 神经网络建模方法实验结果

用 RBF 神经网络方法建立有机质含量预测模型,建模集有机质含量预测值和测定值间的决定系数和均方根误差分别为 0.959 5 和 0.052 0。40 个预测集样本的预测值和测定值之间关系如图 6 所示,决定系数为 0.828 1,均方根误差为 0.164 6,可见 RBF 神经网络预测土壤有机质含量的效果更佳。




图 5 PLS 模型预测值和测定值之间的关系

Fig. 5 Relationship between predicted data of PLS model and measured data

(a) 建模效果图 (b) 预测效果图





图 6 RBF 模型预测值和测定值之间的关系

Fig. 6 Relationship between predicted data of RBF model and measured data

(a) 建模效果图 (b) 预测效果图

## 4 结论

(1) 剔除异常样本对土壤有机质含量的预测精度有很大提高,且不同样本划分方法对模型的建立也存在影响,其中 SPXY 的划分效果最好,随机划分的结果差异较大。

(2) 采用 SPA 方法仅用全部变量的 1.75% 建

模,便可达到较好的效果,表明少数变量确实起到了选取有用信息、减少校正建模计算量的作用。

(3) 主因子变量个数对 PLS 模型的预测效果影响很大,本实验主因子变量数为 11 时预测效果最好,模型预测决定系数为 0.805 8; RBF 神经网络土壤有机质含量预测决定系数为 0.828 1,预测效果比 PLS 更好。

(4)采用光谱分析对土壤有机质进行快速检测是可行的,但土壤光谱复杂,且土质、地形以及环境均会对土壤的漫反射光谱造成影响,在减小和消除

这些干扰、建立普适性和鲁棒性更好的预测模型方面尚需进一步研究。

#### 参 考 文 献

- 1 郑立臣,宇万太,马强.农田土壤肥力综合评价研究进展[J].生态学杂志,2004,23(5):156-161.  
Zheng Lichen, Yu Wantai, Ma Qiang. Advances in the integrated evaluation of farmland fertility[J]. Chinese Journal of Ecology, 2004, 23(5):156-161. (in Chinese)
- 2 何东健,杨成海,杨青,等.面向精准农业的农田土壤成分实时测定研究进展[J].农业工程学报,2012,28(7):78-85.  
He Dongjian, Yang Chenghai, Yang Qing, et al. Research progress of real-time measurement of soil attributes for precision agriculture[J]. Transactions of the CSAE, 2012, 28(7):78-85. (in Chinese)
- 3 陆婉珍.现代近红外光谱分析技术[M].北京:中国石化出版社,2000.
- 4 Adamchuk V I, Hummel J W, Morgan M T, et al. On-the-go soil sensors for precision agriculture[J]. Computers and Electronics in Agriculture, 2004, 44(3):71-91.
- 5 Christy C D. Real-time measurement of soil attributes using on-the-go near infrared reflectance spectroscopy[J]. Computers and Electronics in Agriculture, 2008, 61(1):10-19.
- 6 Croft H, Kuhn N J, Anderson K. On the use of remote sensing techniques for monitoring spatiotemporal soil organic carbon dynamics in agricultural systems[J]. CATENA, 2012, 94:64-74.
- 7 Hunt G R, Salisbury J W. Visible and near infrared spectra of minerals and rocks. I. Silicate minerals[J]. Modern Geology, 1970(1):283-300.
- 8 赵锁劳,彭玉魁.我国黄土区土壤水分、有机质和总氮的近红外光谱分析[J].分析化学研究简报,2002,30(8):978-980.  
Zhao Suolao, Peng Yukui. Analysis of soil moisture, organic matter and total nitrogen content in Loess in China with near infrared spectroscopy[J]. Chinese Journal of Analytical Chemistry, 2002, 30(8):978-980. (in Chinese)
- 9 Sun Jianying, Li Minzan, Zheng Lihua, et al. Real-time analysis of soil moisture, soil organic matter, and soil total nitrogen with NIR spectra[J]. Spectroscopy and Spectral Analysis, 2006, 26(3):427-429.
- 10 李民赞,郑丽华,安晓飞,等.土壤成分与特性参数光谱快速检测方法 & 传感技术[J].农业机械学报,2013,44(3):73-87.  
Li Minzan, Zheng Lihua, An Xiaofei, et al. Fast measurement and advanced sensors of soil parameters with NIR spectroscopy[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(3):73-87. (in Chinese)
- 11 Veronique Bellon-Maurel, Alex McBratney. Near-infrared (NIR) and mid-infrared (MIR) spectroscopic techniques for assessing the amount of carbon stock in soils—critical review and research perspectives[J]. Soil Biology & Biochemistry, 2011, 43(7):1398-1410.
- 12 Vohland M, Besold J, Hill J, et al. Comparing different multivariate calibration methods for the determination of soil organic carbon pools with visible to near infrared spectroscopy[J]. Geoderma, 2011, 166(8):198-205.
- 13 Ji W J, Shi Z, Zhou Q, et al. VIS-NIR reflectance spectroscopy of the organic matter in several types of soil[J]. Journal of Infrared and Millimeter Waves, 2012, 31(3):277-282.
- 14 钱宝,刘凌,肖潇,等.土壤有机质测定方法对比分析[J].河海大学学报:自然科学版,2011,39(1):34-38.  
Qian Bao, Liu Ling, Xiao Xiao, et al. Comparative tests on different methods for content of soil organic matter[J]. Journal of Hohai University: Natural Sciences, 2011, 39(1):34-38. (in Chinese)
- 15 刘雪梅.近红外漫反射光谱检测土壤有机质和速效N的研究[J].中国农机化,2013,34(2):202-206.
- 16 Wu S N, Liu C L, Wu J Z, et al. Outlier sample analysis on near infrared spectroscopy determination for flour ash [C] // International Conference on Measuring Technology and Mechatronics Automation, 2013:781-784.
- 17 Zhu F L, Zhang H L, Shao Y N, et al. Mapping of fat and moisture distribution in Atlantic salmon using near-infrared hyperspectral imaging[J]. Food and Bioprocess Technology, 2014, 7(4):1208-1214.
- 18 党文新,卢晓宇,龚红菊,等.样本集选择对稻谷千粒重 NIR 模型预测精度的影响[J].江西农业学报,2011,23(5):22-24.
- 19 Zhan X R, Zhu X R, Shi X Y, et al. Determination of hesperidin in Tangerine leaf by near-infrared spectroscopy with SPXY algorithm for sample subset partitioning and Monte Carlo cross validation[J]. Spectroscopy and Spectral Analysis, 2009, 29(4):964-968.
- 20 陈彬,刘阁,张贤明,等.连续投影算法的润滑油中含水量的近红外光谱分析[J].红外与激光工程,2013,42(12):3168-3174.  
Chen Bin, Liu Ge, Zhang Xianming, et al. Analysis on near infrared spectroscopy of water content in lubricating oil using successive projections algorithm[J]. Infrared and Laser Engineering, 2013, 42(12):3168-3174. (in Chinese)
- 21 Zou Xiaobo, Zhao Jiewen, Malcolm J W, et al. Variables selection methods in near-infrared spectroscopy[J]. Analytica Chimica Acta, 2010, 667(1-2):14-32.
- 22 高瞻,何东健.基于多光谱的土壤水分测定方法研究[J].农机化研究,2013,35(10):141-145.  
Gao Zhan, He Dongjian. Research on soil moisture measurement based on UV-VIS and NIRS[J]. Journal of Agricultural Mechanization Research, 2013, 35(10):141-145. (in Chinese)
- 23 Nocita M, Stevens A, Toth G, et al. Prediction of soil organic carbon content by diffuse reflectance spectroscopy using a local partial least square regression approach[J]. Soil Biology & Biochemistry, 2014, 68:337-347.